

基于 CVAE 的时变工况轴承运行异常检测*

温广瑞, 周浩轩, 苏宇, 陈雪峰

(西安交通大学机械工程学院 西安, 710049)

摘要 数据驱动异常检测技术被广泛应用于复杂机械设备状态监测中, 工况 (operating conditions, 简称 OCs) 变化会导致监测数据的分布漂移, 使传统数据驱动的异常检测方法的准确性受到极大干扰。为了解决时变工况下工况和健康状态之间的耦合问题, 提出了一个新的特征解耦学习框架。首先, 基于变分自动编码器 (variation auto encoder, 简称 VAE) 构建一个特征解耦条件变分自动编码器 (conditional variation auto encoder, 简称 CVAE) 网络, 实现工况和健康状态的解耦; 其次, 对解耦后的健康状态相关特征进行降维处理, 构建异常指标 (anomaly indicator, 简称 ANI); 然后, 将 ANI 与统计异常阈值相结合, 实现时变工况下轴承的异常检测; 最后, 通过基于时变转速退化的轴承加速疲劳退化实验, 验证了该方法的有效性以及所构建的健康指标在消除时变工况干扰方面的优越性。

关键词 时变工况; 异常检测; 条件变分自动编码器; 轴承

中图分类号 TH165.3; TN911.72

引言

运行状态监测是实现工业设备健康管理的基础, 实时获悉设备的运行状态可以最大限度地提高生产收益和安全性, 最大限度地降低成本和损失。状态监测通过分析传感器收集的数据来实现, 先进的信息处理技术用来从监测数据中获取设备的运行状态。例如, 旋转机械状态监测中, 信号处理方法可以从测量信号中提取特征, 以确定机械的当前运行状态^[1-2]。这通常需要引入故障的先验知识, 当涉及到复杂机械时, 机器学习方法可以通过数据驱动的角度实现状态监测, 来解决故障的先验知识不足的问题^[3], 包括有监督和无监督的学习技术。文献[4]从健康指标构建的角度全面描述了这些方法在旋转机械状态监测上的应用。

基于机器学习的无监督学习技术已经被用于状态监测中, 因其数据驱动特性, 不需要引入先验信息。异常检测 (anomaly detection, 简称 AD) 方法是状态监测的一个典型方法, 由于深度学习理论的发展, 该方法受到极大的关注^[5], 覆盖从工程领域^[6-7]到金融欺诈^[8]。异常检测的基本思想是以自监督学习方式, 使用运行在健康阶段 (无异常) 的机器监测数据构建一个数据表示模型, 通过测试数据的建模误差与重建误差的比较^[9-11]或应用其他特征分析方

法^[12]构建异常分数。目前, 受到最多关注的用于 AD 的深度网络是自编码器, 其变体 VAE 被广泛用于 AD^[13-14]。AD 模型可以成功应用在恒定工况下运行的机器, 然而一旦工况发生变化, 监测数据的分布将发生漂移, 严重影响该方法的有效性。目前, 一些研究关注于从信号处理层面解决该问题^[15-19], 相较于需要先验知识的信号处理方法, 运用基于数据驱动的深度学习方法来解决这个问题较少。

笔者提出一种新的基于数据驱动的异常检测方法, 该方法能够解除时变工况条件下工况与设备的健康状态的耦合, 消除工况变化对异常检测的干扰。与使用时间^[20]、样本标签^[21]和设备编号^[22]作为条件信息来增强 VAE 的模型类似, 提出一种 CVAE 以解决设备异常检测中存在的时变工况干扰问题, 通过在特征空间中解耦工况关联特征与健康状态关联特征, 消除工况干扰进而实现异常检测。在原始 VAE 网络^[23]的基础上, 构建工况信息编码分支。通过可微变换实现工况特征与健康状态特征的融合, 结合各向同性的高斯分布约束与重构误差, 实现工况信息与健康信息的解耦与自监督学习, 消除健康状态特征中的工况干扰。最后, 构建健康指标并结合统计阈值方法实现异常检测, 通过一组时变工况下的轴承加速疲劳实验, 验证了所提出方法在轴承运行异常检测中的有效性。

* 国家重点研发计划资助项目 (2020YFB1710002)

收稿日期: 2022-12-05; 修回日期: 2022-12-30

1 提出的方法

1.1 条件解耦学习

为了解决工况与健康状态之间的耦合问题,笔者提出一种条件信息嵌入的VAE网络。图1为CVAE模型示意图。其中:红色实线表示生成模型 q_θ ;蓝色虚线表示变分近似 p_ϕ ; θ, ϕ 分别为对应的模型参数。

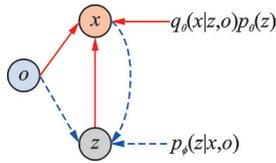


图1 CVAE模型示意图

Fig.1 Illustration of CVAE as a directed graph

从变分推断的角度考虑,潜在特征 z 由包含 x 和 o 联合条件概率密度分布采样得到,同时 z 满足居中的各向同性的多变量高斯先验,即

$$p(z) = \mathcal{N}(z; 0, I) \quad (1)$$

其条件变分近似后验可以表示为

$$\log q_\phi(z|x^{(i)}, o^{(i)}) = \log \mathcal{N}(z; \mu^{(i)}, \sigma^{2(i)}I) \quad (2)$$

其中: i 为样本索引; μ, σ 为编码网络的输出。

设定 x 满足多元高斯分布

$$p(x) = \mathcal{N}(x; \mu, \sigma) \quad (3)$$

条件生成后可表示为

$$\log p_\theta(x|z, o) = \log \mathcal{N}(x; \mu, \sigma^2 I) \quad (4)$$

为了估计参数 θ 和 ϕ , CVAE证据下界可以写为

$$\mathcal{L}(\theta, \phi, x, o) = -\mathbb{D}_{\text{KL}}(q_\phi(z|x, o) \| p(z)) + \mathbb{E}_{q_\phi(z|x, o)}[\log p_\theta(x|z, o)] \quad (5)$$

原始的VAE网络架构包含一对编码器和解码器,以及潜在特征随机重采样层。笔者在此基础上,提出一种条件信息嵌入的特征解耦编码结构以提取解耦特征 m_h 。其中:编码器 E_d 与解码器 G_M 由卷积自编码器^[24]中相似的卷积层组成。图2为笔者提出的特征解耦条件变分自动编码器(feature disentanglement conditional variation auto encoder, 简称FDCVAE)网络结构示意图。FDCVAE中的编码器与解码器的网络结构如表1所示。

变分近似过程 $q_\phi(z|x^{(i)}, o^{(i)})$ 由编码器 E_d ,工况编码器以及可微变换 g 组成。监测数据样本 x 与对应的工况信息 o 输入到编码器 E_d ,表征输入 x 潜在变量 z 分布的均值和方差 μ, σ 由一个线性变换层得到,其中 W 与 B 为线性变换层的权重和偏置。在该方法中,潜在变量 z 的均值 μ 视为解耦工况信息后并关联健康状态特征 m_h ,同时工况信息通过工况编码器(多层感知机)被编码成潜在特征 m_o ,如式(6)、式(7)所示

$$\begin{bmatrix} \mu \\ \sigma \end{bmatrix} = W(E_d(x, o)) + B \quad (6)$$

$$m_o = \text{MLP}(o) \quad (7)$$

与原始VAE中的参数重采样技巧类似,可微变换 g 不同之处在于其加入了特征融合操作。特征 m_h 与特征 m_o 通过相加并结合方差重采样,得到最终的潜在特征 z ,即

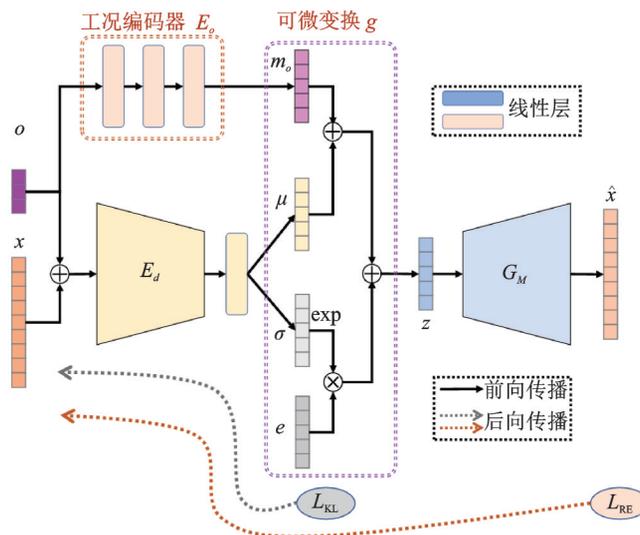


图2 提出的FDCVAE网络结构示意图

Fig.2 Schematic diagram of the proposed FDCVAE network structure

表 1 FDCVAE 中编码器和解码器的网络结构

Tab.1 Network structure of encoder and decoder in FDCVAE

编码器 E_d	解码器 G_M
—	线性层-1
—	线性层-2
—	Unflatten 层
卷积层-1 (1D)	转职卷积层-1 (1D)
池化层-1 (1D)	上采样层-1
批标准化 + Mish(激活函数)	批标准化 + Mish(激活函数)
卷积层-2 (1D)	转职卷积层-2 (1D)
池化层 2 1D	上采样层-2
批标准化 + Mish(激活函数)	批标准化 + Mish(激活函数)
卷积层-3 (1D)	转职卷积层-3 (1D)
池化层-3 (1D)	上采样层-3
批标准化 + Mish(激活函数)	批标准化 + Mish(激活函数)
Flatten 层	Flatten layer
—	线性层-3

$$z = g(m_h, m_o, \sigma, e) = (m_h + m_o) + \sigma e$$

$$(e \sim \mathcal{N}(0, I)) \quad (8)$$

其中: e 为标准正太分布 $\mathcal{N}(0, I)$ 中的采样。

在变分推断中生成过程 $p_\theta(x|z, o)$ 在特征解耦 CVAE 网络中通过生成编码器 G_M 实现, 输入 x 完成过程重构

$$\hat{x} = G_M(z) \quad (9)$$

同时, 与原始 VAE 类似的重构误差和 Kullback-Leibler (KL) 散度可以表示为

$$\mathcal{L}_{RE} = \|x - \hat{x}\|_2^2 \quad (10)$$

$$\mathcal{L}_{KL} = \frac{1}{2} \sum_{n=1}^N (1 + \log((\sigma_n)^2) - (\mu_n)^2 - (\sigma_n)^2) \quad (11)$$

其中: N 与 n 分别为特征 μ, σ 的维度和索引。

特征解耦 CVAE 网络的总体损失函数为

$$\mathcal{L}_{FDCAE} = \alpha \mathcal{L}_{KL} + \beta \mathcal{L}_{RE} \quad (12)$$

其中: α, β 为损失平衡参数。

为了进一步说明损失函数和提出网络中结构的作用关系, 各部分网络参数的更新过程表示为

$$\theta_d \leftarrow \theta_d - l_r \left(\frac{\partial \mathcal{L}_{KL}}{\partial \theta_d} + \frac{\partial \mathcal{L}_{RE}}{\partial \theta_d} \right) \quad (13)$$

$$\theta_o \leftarrow \theta_o - l_r \left(\frac{\partial \mathcal{L}_{RE}}{\partial \theta_o} \right) \quad (14)$$

$$\theta_g \leftarrow \theta_g - l_r \left(\frac{\partial \mathcal{L}_{RE}}{\partial \theta_g} \right) \quad (15)$$

其中: $\theta_d, \theta_o, \theta_g$ 分别为特征解耦编码器 E_d 、工况编码

器 E_o 、生成解码器 G_M 的网络参数; l_r 为学习率。

上述损失函数可以在训练中更新对应的网络参数。

1.2 基于特征解耦 CVAE 的异常检测流程

笔者提出的网络时变工况下轴承异常检测方法的主要步骤如下。

1) 数据准备。获取轴承振动监测信号与工况信息数据, 即监测数据是当前记录的工况下轴承运行产生的。轴承在正常运行阶段的监测数据与工况信息数据作为所提出网络的训练集。

2) 训练特征解耦 CVAE。训练集被用于训练所提出的网络直至收敛。

3) 训练网络部署。在监测阶段, 将每个采样点的监测数据结合工况信息输入到训练好的网络中, 解耦编码器 E_d 输出解耦后的特征 m_h , 该特征可以被当做解除工况信息耦合的关联轴承健康状态的特征。

4) 基于解耦特征 m_h 的异常检测。引入基于统计的方法进行轴承异常运行状态的分析判定, 通过构建异常指标来表示当前轴承的运行状态。首先, 运用主成分分析 (principal component analysis, 简称 PCA) 对特征 m_h 进行降维以获取异常指标; 其次, 引入 3sigma 准则设定阈值, 实现异常状态检测, 即

$$|\text{ANI}_t - \mu_{\text{ANI}_{\min}}| > 3\sigma_{\text{ANI}_{\min}} \quad (16)$$

其中: $\mu_{\text{ANI}_{\min}}, \sigma_{\text{ANI}_{\min}}$ 分别为异常指标在训练阶段的均值和方差。

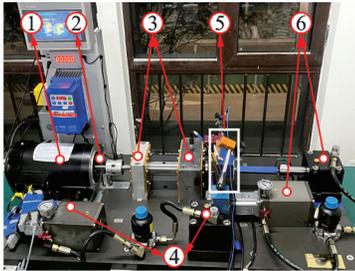
正确运用 3sigma 的前提是假定数据服从正态分布 $\mathcal{N}(\mu_{\text{ANI}_{\min}}, \sigma_{\text{ANI}_{\min}})$ 。由于受到 KL 散度损失 \mathcal{L}_{KL} 的正则化作用, 消除工况信息的特征 m_h 的分布可以认为是趋近于正太分布, 所以这里引入 3sigma 准则是合理的。

2 实 验

2.1 方法验证

通过一组全寿命轴承退化实验数据来证明所提方法的有效性, 轴承加速疲劳实验平台如图 3 所示。PCB068A11 加速度计安装在轴承座的径向, 图 4 为传感器安装位置。考虑轴承的时变转速工况, 实验设定轴承的运行工况在一个较长的时间范围内变化, 每一个转速保持 10 h 不变。图 5 为时变转速设

定示意图。测试轴承的轴向和径向载荷设为恒定值,其中轴向和径向载荷分别为0.5,5 kN。采样频率为20.48 kHz,采样间隔设为10 min,每个样本包含3 s的振动信号。测试轴承在运行一段时间后出现了内圈及滚动体的故障,测试轴承最终的点蚀和剥落故障如图6所示。



1-交流电机; 2-关键相位传感器;
3-支撑轴承; 4-轴向加载器;
5-被测深沟球轴承(ER-16K); 6-径向加载器

图3 轴承加速疲劳实验平台

Fig.3 The specific test rig setup of the experiment

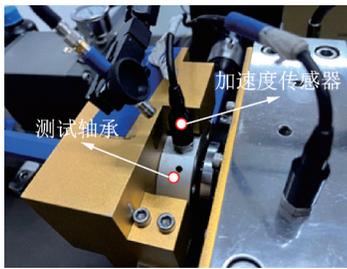


图4 传感器安装位置

Fig.4 The location of sensor mounting

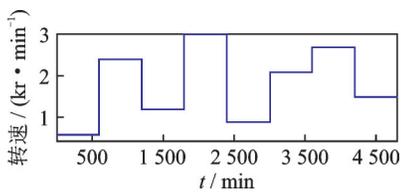


图5 时变转速设定示意图

Fig.5 The rotating speed setup



图6 测试轴承最终的点蚀和剥落故障

Fig.6 Pitting and spalling faults of tested bearing at the end

测试轴承全寿命期间的振动信号如图7所示。可以发现,由于受到时变工况的影响,轴承的振动信号受到工况干扰严重,无法直接通过观测时域信号准确检测异常发生的时间。这种情况是笔者重点描述和

关注的问题,且适用所提出的方法。在正常监测情况下,机器主要在健康状态下运行,可以认为运行初期的轴承是健康的,在这些阶段收集的监测数据可以作为训练数据来训练AD模型。由于频谱不受相位信息的干扰,所以采用傅里叶变换来表示每个样本,这里选择健康状态和最终故障状态下的频谱进行说明,设前400个数据点为训练集,其余的为测试集。

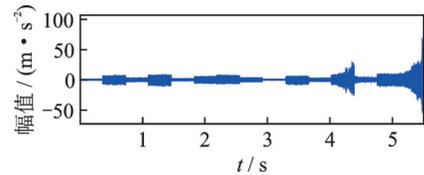


图7 测试轴承全寿命期间的振动信号

Fig.7 Vibration signal of tested bearing during the whole life cycle

为了减少网络参数,将输入数据样本截取2560个数据点,通过傅里叶变换转换为相同长度的频谱。同时,将加速疲劳实验获得的全寿命数据分为训练集和测试集,训练集只包括前50个振动信号($50 \times 3 \times 8$),其余200个运行故障信号($200 \times 3 \times 8$)作为测试集。此外,本实验中遇到的工况包含5个典型的恒定速度。采用独热编码对速度信息进行编码,以减少条件编码器的参数数量。将训练数据用于训练特征解耦CVAE网络。优化器使用Adam,学习率为 1×10^{-3} 。训练数量设为100,异常检测结果如图8所示,在构建的ANI中,时变工况的干扰被有效消除了。同时,673号数据点及后续数据点被检测为异常状态。测试轴承全寿命数据解耦特征可视化如图9所示,显示了运行至故障数据的t-分布领域嵌入(t-distributed stochastic neighbor embedding,简称t-SNE)可视化特征,描述了消除工况干扰后可视化特征的紧凑分布。

异常点673及其周围的点672,674的原始频谱

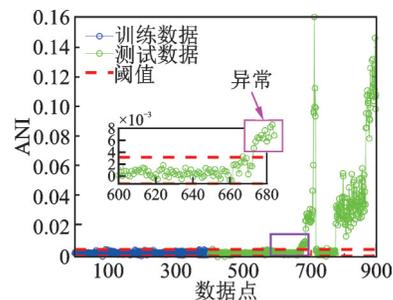


图8 异常检测结果

Fig.8 Result of the anomaly detection

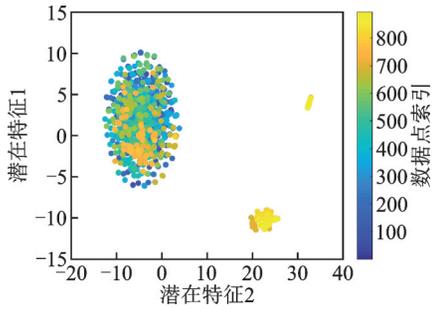


图9 测试轴承全寿命数据解耦特征可视化

Fig.9 Feature visualization of the disentangled feature of entire run-to-failure data of tested bearing

和通过谱峭度滤波后的信号及其对应的包络谱如图10,11所示。

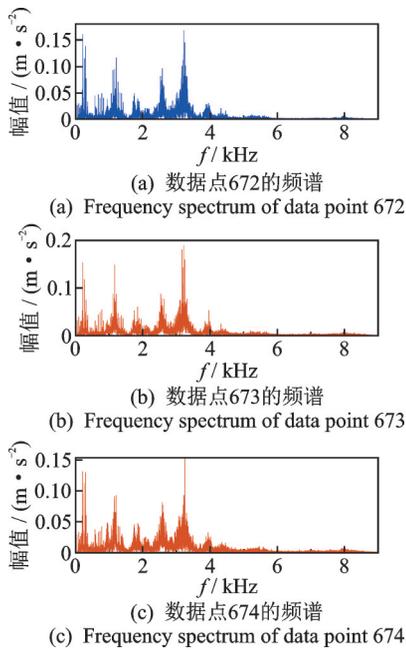


图10 异常点673及其周围的点672,674的原始频谱

Fig.10 Frequency spectrum of detected anomaly data point 673 and its neighboring data points 672, 674

滤波信号的包络谱表明,所提出方法检出的异常数据点在某些频率上,谱的分布变得稀疏。与图11(d)所示的正常数据点相比,转频及其倍频成分被突出。此外,瞬态冲击也呈现在时域信号中。相反,原始频谱没有显示出正常和异常数据点之间的明显差异,这进一步说明了所提出方法具有良好的异常敏感性。

2.2 对比分析

使用均方根(root mean square,简称RMS)和峰度分别测量振动信号的能量变化和分布差异,后者使用从潜在特征和原始VAE的重建误差中得到

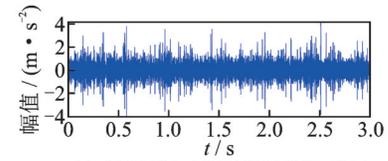
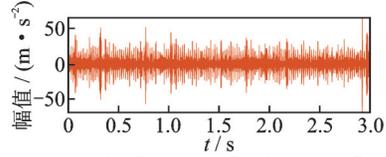
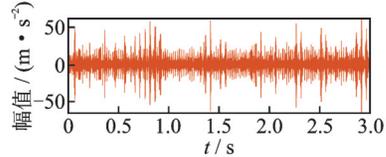
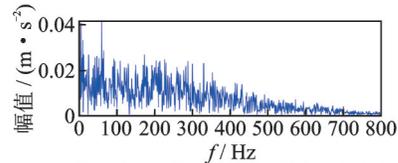
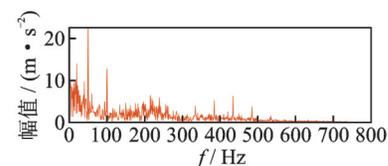
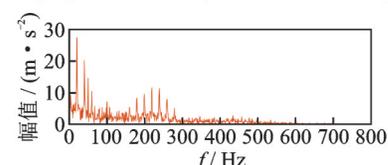
(a) 数据点672带通滤波后的信号
(a) Band-pass filtered signal of data point 672(b) 数据点673带通滤波后的信号
(b) Band-pass filtered signal of data point 673(c) 数据点674带通滤波后的信号
(c) Band-pass filtered signal of data point 674(d) 数据点672带通滤波后所对应的包络谱
(d) Envelope spectrum of data point 672 after band-pass filtering(e) 数据点673带通滤波后所对应的包络谱
(e) Envelope spectrum of data point 673 after band-pass filtering(f) 数据点674带通滤波后所对应的包络谱
(f) Envelope spectrum of data point 674 after band-pass filtering

图11 异常点673及其周围点672,674通过带通滤波后的信号及其对应的包络谱

Fig.11 Band-pass filtered signals and envelop spectrums of data points 673 and its neighboring data points 672, 674

ANI。对比方法获得的异常检测结果如图12所示。图12(a)中,有效值和峭度受到时变工况的干扰,这2种由VAE导出的数据驱动的ANI仍然不能克服由于工况变化而产生的波动。

由于ANI分布不满足高斯分布的假设,考虑3sigma阈值设定方法的前提条件,这些方法在本实验中是失效的。此外,将对比方法VAE中潜在特征可视化,如图13所示,发现不同时刻的数据点是重

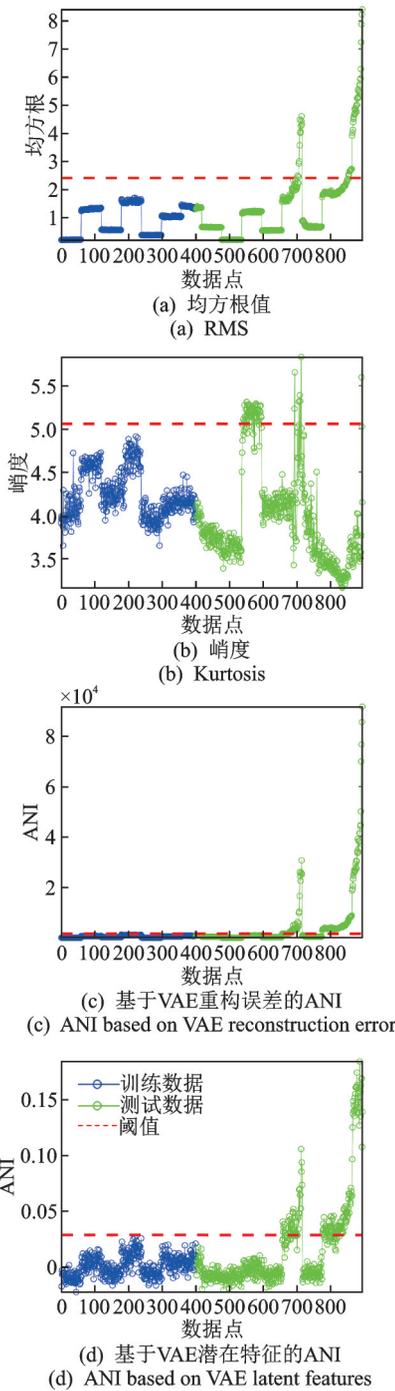


图 12 对比方法获得的异常检测结果

Fig.12 The AD results of AD of obtained by the comparison methods

叠的。相对于所提出方法,类内分布并不紧凑,这进一步说明了所提方法的优越性。

2.3 训练集鲁棒性分析

通过设置包含不同工况信息的训练集和测试集来测试所提模型的对于工况的泛化性能。表 2 为训练集和测试数据集信息。每个测试的训练集和测试集涵盖了不同范围的工况,训练集中的工况在测试

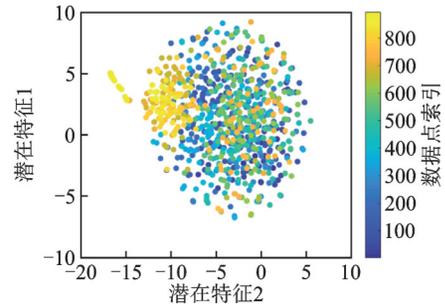


图 13 对比方法 VAE 中潜在特征可视化

Fig.13 Visualization of potential features in the comparison method VAE

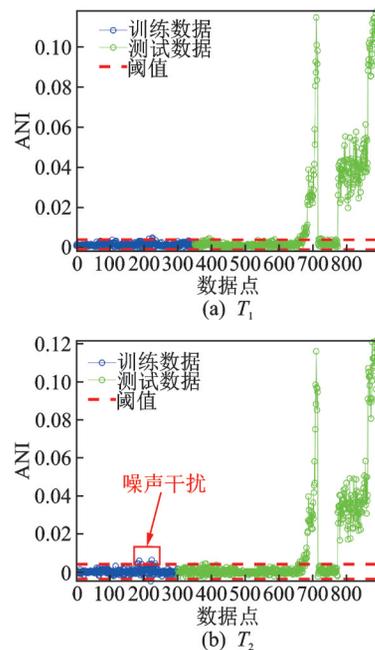
表 2 训练集和测试数据集信息

Tab.2 Training and testing dataset information

测试编号	训练集样本数	测试集样本数
T_1	350	544
T_2	300	594
T_3	250	644
T_4	200	694
T_5	150	744

集中并没有完全覆盖。

在相同的网络训练超参数设置下,工况泛化测试结果如图 14 所示。除了图 14(e)所示的测试 T_5 外,在所有情况下都能有效消除干扰,尽管有些结果含有噪声干扰。发现 T_5 中的干扰对应 2 个高速工况,而这 2 个高速工况并没有包含在测试的训练集中。另外,比较其他测试结果,可以得出一个预期的结论:当工况的上下限被包含在训练集中,模型可以在该范围内实现更好的泛化。



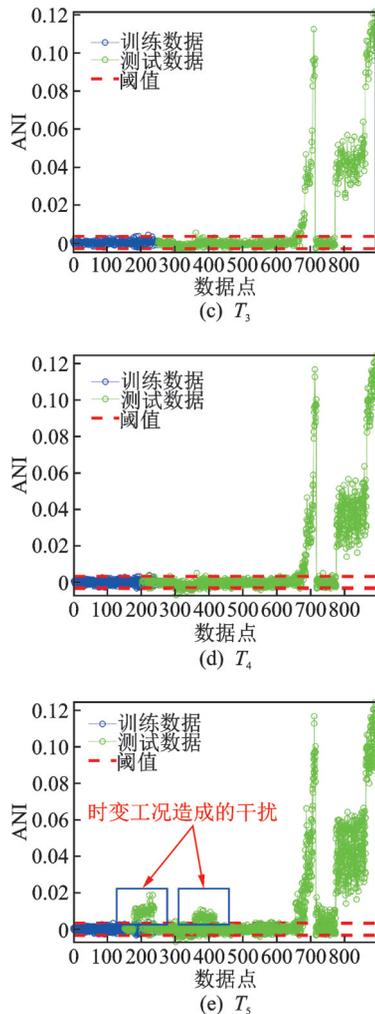


图 14 工况泛化测试结果

Fig.14 The result of OCs generalization tests

3 结束语

运行异常检测技术对于轴承安全和可靠运行至关重要,时变工况问题制约了数据驱动的AD在实际工业中的应用,为了实现数据驱动的时变工况轴承运行异常检测,笔者在VAE的基础上提出了一种特征解耦条件变分自动编码器并应用于轴承的运行异常检测。通过自监督学习解耦工况特征和健康状态特征,消除时变工况的干扰,进而实现异常检测。通过轴承加速疲劳寿命实验验证了所提出的方法的有效性。

笔者所提出的嵌入工况信息的自监督学习方法创新性地解决了数据驱动异常检测方法无法克服的时变工况干扰问题,形成了一种无需故障先验知识、“数据发生”的时变工况异常检测新方法。该方法可以进一步地推广到涉及时变工况的无先验故障知识的其他机械设备异常检测。

参 考 文 献

- [1] ZHOU H, LI H, LIU T, et al. A weak fault feature extraction of rolling element bearing based on attenuated cosine dictionaries and sparse feature sign search [J]. ISA Trans, 2020, 97:143-154.
- [2] ZHOU H, WEN G, ZHANG Z, et al. Sparse dictionary analysis via structure frequency response spectrum model for weak bearing fault diagnosis [J]. Measurement, 2021, 174: 109010.
- [3] ZHOU H X, HUANG X, WEN G R, et al. Convolution enabled transformer via random contrastive regularization for rotating machinery diagnosis under time-varying working conditions[J]. Mechanical Systems and Signal Processing, 2022, 173: 109050.
- [4] ZHOU H, HUANG X, WEN G, et al. Construction of health indicators for condition monitoring of rotating machinery: a review of the research[J]. Expert Systems with Applications, 2022, 203: 117297.
- [5] CHALAPATHY R, CHAWLA S. Deep learning for anomaly detection: a survey [J]. ArXiv Eprints, 2019, arXiv: 1901.03407.
- [6] LI Y, FANG H, CHEN J. Anomaly detection and identification for multiagent systems subjected to physical faults and cyberattacks [J]. IEEE Transactions on Industrial Electronics, 2020, 67(11): 9724-9733.
- [7] ZHANG Y C, DONG Z Y, KONG W C, et al. A composite anomaly detection system for data-driven power plant condition monitoring[J]. IEEE Transactions on Industrial Informatics, 2020, 16(7): 4390-4402.
- [8] HILAL W, GADSDEN S A, YAWNEY J. Financial fraud: a review of anomaly detection techniques and recent advances[J]. Association for Computing Machinery, 2022, 193:0957-4174.
- [9] CHEN J, LI J, CHEN W, et al. Anomaly detection for wind turbines based on the reconstruction of condition parameters using stacked denoising autoencoders[J]. Renewable Energy, 2020, 147: 1469-1480.
- [10] WU J, ZHAO Z, SUN C, et al. Fault-attention generative probabilistic adversarial autoencoder for machine anomaly detection [J]. IEEE Transactions on Industrial Informatics, 2020, 16(12): 7479-7488.
- [11] HUANG X, WEN G, DONG S, et al. Memory residual regression autoencoder for bearing fault

- detection [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-12.
- [12] OU X, WEN G, HUANG X, et al. A deep sequence multi-distribution adversarial model for bearing abnormal condition detection [J]. Measurement, 2021, 182: 109529.
- [13] AN J, CHO S. Variational autoencoder based anomaly detection using reconstruction probability [J]. Special Lecture on IE, 2015, 2(1): 1-18.
- [14] DOERSCH C. Tutorial on variational autoencoders [J]. Stat, 2016, 1050: 13.
- [15] SCHMIDT S, ZIMROZ R, HEYNS P S. Enhancing gearbox vibration signals under time-varying operating conditions by combining a whitening procedure and a synchronous processing method[J]. Mechanical Systems and Signal Processing, 2021, 156: 107668.
- [16] SCHMIDT S, HEYNS P S, GRYLLIAS K C. An informative frequency band identification framework for gearbox fault diagnosis under time-varying operating conditions[J]. Mechanical Systems and Signal Processing, 2021, 158: 107771.
- [17] SCHMIDT S, GRYLLIAS K C. The anomalous and smoothed anomalous envelope spectra for rotating machine fault diagnosis [J]. Mechanical Systems and Signal Processing, 2021, 158: 107770.
- [18] SCHMIDT S, GRYLLIAS K C. Combining an optimisation-based frequency band identification method with historical data for novelty detection under time-varying operating conditions [J]. Measurement, 2021, 169: 108517.
- [19] SCHMIDT S, HEYNS P S. Normalisation of the amplitude modulation caused by time-varying operating conditions for condition monitoring [J]. Measurement, 2020, 149: 106964.
- [20] SHULMAN Y. Unsupervised contextual anomaly detection using joint deep variational generative models [J]. Arxiv Eprints, 2019, arXiv: 1904.00548.
- [21] POL A A, BERGER V, GERMAIN C, et al. Anomaly detection with conditional variational autoencoders [C] // 2019 18th IEEE International Conference on Machine Learning and Applications. [S. l.]: IEEE, 2019: 1651-1657.
- [22] PUROHIT H, ENDO T, YAMAMOTO M, et al. Hierarchical conditional variational autoencoder based acoustic anomaly detection [C] //2022 30th European Signal Processing Conference (EUSIPCO). [S. l.]: IEEE, 2022: 274-278.
- [23] KINGMA D P, WELING M. Auto-encoding variational bayes [J]. Stat, 2014, 1050: 1.
- [24] MASCI J, MEIER U, CIREŞAN D, et al. Stacked convolutional auto-encoders for hierarchical feature extraction [C] // International Conference on Artificial Neural Networks. [S. l.]: Springer, 2011: 52-59.



第一作者简介:温广瑞,男,1976年7月生,教授、博士生导师。主要研究方向为机械运行状态故障诊断及性能维护、现场动平衡理论及方法研究、远程及现场监测与诊断系统开发。担任中国机械工程学会高级会员、陕西省机械工程学会理事、中国振动工程学会动态测试专业委员会理事及西北分会秘书长、国家自然科学基金委工程与材料科学部同行评审专家、教育部专家信息库专家。主持国家自然科学基金项目2项、教育部新世纪优秀人才支持计划项目1项、国家博士后科学基金项目2项、国家航空科学基金项目1项、陕西省工业攻关项目1项、大型企事业合作研究项目20余项,以主要完成人承担国家“九七三”课题、国家“八六三”项目、国家数控机床重大专项和陕西省科技创新项目多项。发表论文60余篇(SCI/EI收录30篇),申请国家发明专利13项,取得国家软件著作权11项。获得陕西省第10届青年科技奖、中国振动工程学会青年科技奖、教育部新世纪优秀人才、中国机械工程学会青年科技成就奖、西安交通大学优秀博士后等荣誉。

E-mail: grwen@mail.xjtu.edu.cn